

INFLUÊNCIA DO EL NIÑO E DA LA NIÑA NA PREVISÃO INTRA- HORÁRIA DA IRRADIAÇÃO SOLAR GLOBAL HORIZONTAL

Juliana Silva Brasil¹
Felipe Pinto Marinho²
Paulo Alexandre Costa Rocha³

INTRODUÇÃO

A crescente representatividade da energia solar na matriz energética brasileira traz consigo questões relativas à complementaridade de abastecimento, uma vez que a fonte solar é intermitente [1]. Seja para uso doméstico quanto em parques solares, que fornece energia para a rede elétrica, é útil saber quando ocorrerão reduções na disponibilidade do recurso solar. Essa informação evita quedas no fornecimento de eletricidade bem como o consumo desnecessário de outras fontes [2].

O estado do Ceará se destaca na geração de energia por fontes renováveis, dentre as quais a solar. A região é favorecida pelos altos índices de incidência solar [3]. A geração solar na região representa uma alternativa à produção hidrelétrica local, que é bastante afetada pelos períodos de escassez de chuvas, e que geralmente acarretam aumento na tarifa de energia.

Previsões confiáveis de irradiação são uma alternativa para identificar prováveis períodos de redução na disponibilidade do recurso solar. Estas previsões podem ser feitas em diferentes horizontes temporais, de minutos a dias, estas necessárias para o agendamento de manutenções preventivas e àquelas necessárias para previsão de quedas de fornecimento [1].

O El niño e a La niña são fenômenos climáticos de aquecimento e resfriamento, respectivamente, da camada mais superficial do oceano Pacífico equatorial [4]. Esses eventos alteram os regimes de chuvas e ventos, provocando impactos globais no clima [5].

O trabalho tem por objetivo avaliar a influência da intensidade dos fenômenos climáticos El niño e La niña, *The Oceanic Niño Index* (ONI), como preditor para a realização de previsões de irradiação solar global horizontal em horizontes de tempo de 2 min, 10 min e 30 min, utilizando os algoritmos de aprendizagem supervisionada Florestas Aleatórias (RF) e Rede Neural Artificial Percéptron de Múltiplas Camadas (ANN), além de um modelo de persistência, que funciona como uma cota inferior para o desempenho de outros modelos de previsão.

Os resultados apontaram que a adição do preditor ONI reduziu a raiz do erro quadrático médio (RMSE) relacionado à previsão, bem como verificou-se que tanto o RF quanto o ANN apresentaram um menor valor de RMSE quando comparado com o modelo de persistência. Sendo o RF o modelo de melhor desempenho.

1 Mestranda do Curso de Engenharia Mecânica PPGEM da Universidade Federal do Ceará - UFC, julianasbra@gmail.com;

2 Mestrando do Curso de Engenharia Mecânica PPGEM da Universidade Federal do Ceará - UFC, felipe.pinto.marinho@gmail.com;

3 Professor orientador: Doutor, Departamento de Engenharia Mecânica - UFC, paulo.rocha@ufc.br.

METODOLOGIA

Os dados foram coletados na cidade de Fortaleza, Ceará, $3^{\circ} 43' 2''S$, $38^{\circ} 32' 35'' O$, durante os anos de janeiro de 2007 a dezembro de 2013 (com exceção do anos de 2009 e 2011). Os dados meteorológicos foram obtidos por meio da Fundação Cearense de Meteorologia e Recursos Hídricos - Funceme [6], os dados de irradiação solar foram coletados pelo Laboratório de Energia Solar e Gás Natural - LESGN, da Universidade Federal do Ceará.

Foram considerados neste trabalho os preditores: ano, dia e horário da aquisição das observações, temperatura e umidade relativa do ar, velocidade e direção do vento, precipitação, irradiação do instante atual e irradiação de 5 instantes anteriores (2 min, 4 min, 6 min, 8 min, 10 min).

Por meio dos valores de irradiação solar calculou-se o índice de céu claro (Kt) que é a razão entre a irradiação solar medida e a irradiação solar máxima que atinge a terra em um dado instante [7]. O dia do ano foi normalizado a fim de reduzir sua amplitude de valores [8].

Também foi acrescentado como preditor o *The Oceanic Niño Index* (ONI), que avalia a intensidade do El Niño e da La Niña, variando de -4 (La Niña forte) a 4 (El Niño forte). Essa informação foi obtida pelo *National Oceanic and Atmospheric Administration* (NOOA) órgão do governo estadunidense [9].

MODELOS

Florestas Aleatórias - Trata-se de um método de árvores de regressão, que consiste em gerar várias árvores de decisão que têm posteriormente seus resultados combinados. Por agregar muitos modelos é considerado um *Ensemble*. Este método é uma árvore regressão com um procedimento de *Bootstrap Aggregation* (BAGGING), mas com a característica de selecionar aleatoriamente m preditores do número total de atributos a fim de reduzir a variância do modelo [10].

Para determinar o número de árvores ótimo para a realização das previsões foi utilizado o procedimento de amostragem validação cruzada [11].

ANN - é um tipo de rede neural classicamente aplicada em problemas de previsão [12]. A arquitetura da rede utilizada neste trabalho consiste de 3 camadas, entrada, intermediária, ou oculta, e saída. O método recebe esse nome por se assemelhar às transmissões entre neurônios no corpo humano. Caracteriza-se pela presença de neurônios, ou nós, que ao receberem as informações de neurônios anteriores, lhes atribuem pesos distintos e posteriormente as somam. Esse somatório passa por uma função de ativação, que fornece a resposta estimada [13].

A obtenção do número de neurônios da camada intermediária que fornece o menor erro para a previsão foi feita por meio da realização de sucessivas abordagens de subconjunto de validação.

Persistência - Consiste de um modelo para servir de parâmetro de erro para os demais métodos. Nele considerou-se que a irradiação do instante posterior seria igual à irradiação do instante anterior.

MÉTRICAS DE ERRO

São necessárias para comparar os métodos e avaliar a adequação destes ao banco de dados trabalhado.

-Raiz do Erro Quadrático Médio (RMSE) - O RMSE é um importante parâmetro de avaliação do ajuste de um modelo, é calculado pela raiz do erro médio ao quadrado, onde o

erro médio é a média da diferença entre o valor predito e o valor real. É dado na mesma unidade da variável predita.

- Raiz do Erro Quadrático Médio Relativo (nRMSE) - É a razão entre o RMSE e a média dos valores reais da variável. É obtido na forma de porcentagem. Essa métrica de erro fornece uma faixa de classificação para a previsão, a saber: $nRMSE < 10\%$ excelente, $10\% < nRMSE < 20\%$ bom, $20\% < nRMSE < 30\%$ razoável e $nRMSE \geq 30\%$ ruim [14].

- Erro Absoluto Médio (MAE) - É a média do valor absoluto da diferença entre o valor predito e o valor real. Nesta métrica os erros individuais são ponderados igualmente pela média, diferentemente do RMSE.

- Erro Absoluto Médio Normalizado (nMAE) - É a razão entre o MAE e a média dos valores reais da variável.

RESULTADOS E DISCUSSÃO

Para ambas as previsões, com e sem o preditor ONI, e para todos os modelos, verificou-se que os valores de nRMSE aumentaram quanto mais distante estavam os horizontes temporais, conforme sugerido em [15].

Considerando o preditor ONI, o método que apresentou menor nRMSE para os três tempos considerados foi o RF (25,24% - 2min, 31,39% - 10min, 33,08% - 30min), seguido do ANN (26,22% - 2min, 33,44% - 10min, 45,38% - 30min) e do modelo de persistência (29,28% - 2min, 40,28% - 10min, 50,77% - 30min). Desconsiderando o preditor ONI, verificou-se comportamento similar em relação aos métodos de melhor desempenho, entretanto os valores de nRMSE foram, no geral, ligeiramente maiores, o que indica que a adição do preditor ONI influencia positivamente no desempenho dos métodos. Os valores de nRMSE para esta segunda situação foram: RF (25,23% - 2min, 31,42% - 10min, 33,11% - 30min) e ANN (26,36% - 2min, 33,93% - 10min, 38,83% - 30min).

Quanto ao MAE e ao nMAE o comportamento foi similar ao do RMSE, com o RF apresentando melhor desempenho (0,0776 - 2 min, 0,1501 - 2min, respectivamente) para o horizonte de 2 min, considerando o preditor ONI.

As previsões para 2 min foram as únicas que apresentaram valores de nRMSE dentro da faixa 'razoável'. As previsões de 10min e 30min apresentaram resultados classificados dentro da faixa 'ruim' [14].

CONSIDERAÇÕES FINAIS

Realizou-se previsões de irradiação solar global usando os métodos, RF, ANN e de persistência. A adição da intensidade do El niño e La niña, ONI, como preditor melhorou a performance dos modelos, sendo o algoritmo de florestas aleatórias o método que melhor se adequou aos dados em estudo. Verificou-se que quanto mais distante o horizonte temporal maior o erro para todos os métodos, com e sem o preditor ONI.

Aprimorar a validação cruzada k-fold para o algoritmo de florestas aleatórias e a escolha dos parâmetros da rede neural (número de neurônios e de camadas) são alternativas para melhorar os resultados, bem como verificar quais funções de ativação da ANN são mais adequadas ao banco de dados.

Palavras-chave: Previsão, Aprendizagem de máquina, Irradiação solar global, El niño e La Niña.

AGRADECIMENTOS

Os autores agradecem a Coordenação para o Aperfeiçoamento de Pessoal de Ensino Superior (CAPES) pelo suporte financeiro na forma de bolsa de estudo e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS

- [1] Notton G, Nivet ML, Voyant C, Paoli C, Darras C, Motte F, Fouilloy A. Intermittent and stochastic character of renewable energy sources: consequences, cost of intermittence and benefit of forecasting. *Renewable and Sustainable Energy Reviews* 2018; 87:96-105.doi:10.1016/j.rser.2018.02.007.
- [2] Quing X, Niu Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy* 2018; 148:461-468. doi:10.1016/j.energy.2018.01.177.
- [3] Menezes OL, Oliveira JL, Vasconcelos FC, Pereira JMR, Sakamoto MS. Atlas solarimétrico do Ceará 1963-2010. Fundação Cearense de Meteorologia e Recursos Hídricos-Funceme 2011.
- [4] Kayano MT, Andreoli RV, Souza RAF, Garcia SR, Calheiros AJP. El niño e la niña nos últimos 30 anos: diferentes tipos. Instituto Nacional de Pesquisas Espaciais, INPE.
- [5] Mohammadi K, Goudarzi N. Study of inter-correlations of solar radiation, wind speed and precipitation under the influence of el niño southern oscillation (ENSO) in California. *Renewable Energy* 2018; 120:190-200.doi:10.1016/j.renene.2017.12.069.
- [6] Plataforma de Coleta de Dados - PCD - Funceme. <http://funceme.br/pcd/> (accessed September 20, 2019).
- [7] Duffie JA, Beckman WA. *Solar Engineering of Thermal Processes*. John Wiley & Son, 2006.
- [8] Zhu T, Xie L, Wei H, Wang H, Zhao X, Zhang K. Clear-sky direct normal irradiance estimation based on adjustable inputs and error correction. *Journal of Renewable and Sustainable Energy* 2019; 11.doi:10.1063/1.5094808.
- [9] Historical El niño / La niña episodes (1950 - present). https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php (accessed May 12, 2019).
- [10] Benali L, Notton G, Fouilloy A, Voyant C, Dizene R. Solar radiation forecasting using artificial neural network and random forest methods: applications to normal beam, horizontal diffuse and global components. *Renewable Energy* 2019; 132:871-884.doi:10.1016/j.renene.2018.08.044.
- [11] Rohani A, Taki M, Abdollahpour M. A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy* 2018;115:411-422.doi:10.1016/j.renene.2017.08.061.
- [12] Rocha PAC, Fernandes JL, Modolo AB, Pontes RJ, Vieira ME, Bezerra CA. Estimation of daily, weekly and monthly global solar radiation using ANNs and a long data set: a case study of Fortaleza, in Brazilian Northeast region. *International Journal of Energy and Environmental Engineering* 2019.doi:10.1007/s40095-019-0313-0.
- [13] Inman RH, Pedro HTC, Coimbra CFM. Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science* 2013;39:535-576.doi:10.1016/j.pecs.2013.06.002.
- [14] Li MF et al. General models for estimating daily global solar radiation for different solar radiation zones in mainland China. *Energy Conversion and Management* 2013; 70:139-148.doi:10.1016/j.enconman.2013.03.004.

[15] Pedro HTC, Coimbra CFM. Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances. Renewable Energy 2015; 80:770-782. doi:10.1016/j.renene.2015.02.061.